情報処理学会論文誌 Vol. 52 No. 2 866–876 (Feb. 2011)

情報利得を基にした移動状態推定による携帯電話搭載型消費カロリー計測システム

南川敦宣[†1] 小林亜令[†1] 横山浩之[†1]

本稿では携帯電話端末搭載の加速度センサを利用した消費カロリー計測システムを提案する．提案システムでは，日常環境において高精度に消費カロリー推定を実施するために，加速度計測値から移動状態を推定する．また端末の所持状態に依存せずロバストな推定を行うために，加速度計測値をシンボル化した後，さらに複数のシンボルの時系列データを使って確率的に移動状態を推定する．さらに推定時に着目するシンボルを，情報利得を基準に決定することで，推定処理負荷を軽減している．多数の被験者をともなった実証実験において，提案手法が移動状態および消費カロリーの推定において有効に機能することが示された．

Energy Expenditure Monitoring System on Mobile Phone Using Information Gain Based Locomotion Estimation Method

Atsunori Minamikawa,[†1] Arei Kobayashi[†1] and Hiroyuki Yokoyama[†1]

This paper describes a new daily energy expenditure monitoring system using the accelerometer installed in mobile phone. In order to estimate accurate energy expenditure in daily usage, our system estimates the locomotion of the user from the accelerometer measurements before calculating the energy expenditure. In addition, our system uses time series of multiple symbols which derive from the power spectrums of the accelerometer signals for the locomotion estimation in order to achieve robustness against sudden vibration patterns and the posture of the mobile phone. Through the demonstration experiment with the multiple subjects, our system has proved its effectiveness and validation in daily usage.

1. はじめに

メタボリックシンドロームが大きな社会問題となってきている．生活習慣病へつながる大きな要因であるため，医療関係者からも非常に注目を集めている．メタボリックシンドロームの予防にあたっては，日常生活における食料等からの摂取エネルギーと消費カロリーとのエネルギーバランスが重要であるため，日々これらの状態を監視しておくことは，予防の第1歩となる．このうち消費カロリーを計測する最も標準的な方法としてダグラスバッグ法がある．ダグラスバッグ法は専用のガスマスクとガスアナライザを装着し二酸化炭素の排出量から消費カロリーを計測する方法であり，高精度に計測することが可能である．しかしながらこれらの機器の装着によって行動が大きく制限されるため，日常計測に使用するには適していない．エネルギー代謝測定室のように，部屋のガス濃度や流量を測定する方法では，被験者が機器を装着する必要がないものの，活動が部屋内に制限されるため，やはり日常計測には適さない．これらに対して，心拍や体温等の生体情報を使用する推定法もある．ダグラスバッグ法よりは精度が劣るものの，正確に消費カロリーを推定できる方法として，いくつかの計測機器が医療，スポーツ計測の場で使用されている．たとえばSenseWear[1)]は生体情報を利用した消費カロリー計測機器の1つで，加速度，表面皮膚抵抗，熱流束，皮膚温度の計測値を統合して，消費カロリーを推定している．しかし，生体情報を得るには機器を直接皮膚に接触させる必要があり，被験者に心的負荷がかかるため，日常的に使用するには，抵抗を感じるユーザも少なくない．

こういった背景の中，携帯電話が日常計測機器として期待されている．携帯電話は，多くの人がコミュニケーションや情報収集のため，ほぼ常時所持していること，また，近年は様々なセンサが搭載されて始めていることが主な理由である．なかでも加速度センサはカロリー消費量と関係の強い人の動きを検出できるため，有力なデバイスとして注目されている．たとえばBouten ら[2)]とHendelman ら[3)]は人体に装着したセンサから得られる加速度の大きさと消費カロリーとが線形の関係にあることを示している．また，Choi ら[4)]，Haapalainen ら[16)]は運動状態ごとに線形モデルを適用して，運動によって生じる加速度の大きさから消費カロリーの推定を試みている．Lester ら[17)]は，加速度計測値から歩行・走行・停止を識別して，消費カロリーを推定しており，フィールド試験において，ダグラス

†1 株式会社 KDDI 研究所
KDDI R&D Laboratories, Inc.

© 2011 Information Processing Society of Japan

バック法と比較して推定誤差 21%を達成している．また Li[18] は心電図と加速度センサによって走行と自転車の運動状態を計測するシステムを提案している．いずれの研究においても，消費カロリーを正確に推定するにあたり，運動状態の推定は重要な要素となっている．

加速度センサを使った運動状態の推定に関する研究は数多く行われており，Kem[5] は複数のセンサを体の複数の箇所に装着し，起立，着席，握手等の動作の推定を行っている．Intille ら[6),7)] らは両手首，両足首そして太股の 5 カ所にセンサを装着し 20 種類の動作を識別している．また Wang ら[8)] も同様の手法で歩き方の推定を行っている．これらの研究は複数箇所にセンサを固定する必要があり，実利用という観点から現実的でない．Iso ら[9)] は単一の 3 軸加速度センサで計測される波形を自己組織化マップによってシンボル化し，階段昇降を含めた歩行パターンの識別を行っている．しかし，あらかじめユーザごとに歩行パターンを学習する必要があること，また端末の所持状態が胸とズボンのポケットのみに制限されていること等から，ユーザや所持状態に依存しない用途で利用すると精度が悪化することが想定される．また Kawahara ら[10)] も加速度計測値の FFT 解析データとセンサの重力方向に対する角度を基に簡単な決定木によって，起立，着席，走行，歩行の識別を行っているが，その他の移動状態までは推定しておらず，また他の研究と同様に，推定処理においてセンサデバイスの設置場所に強く依存している．

文献 11) では 3 軸加速度センサ，GPS，マイクを複合的に用いて歩行，走行だけでなく，自転車や電車，自動車といった移動状態を推定していたが，推定精度の向上のため，時系列の計測データに対して隠れマルコフモデル（HMM：Hidden Markov Model）を使用しており，処理負荷が大きく，携帯電話で常時実行するには消費電力の問題があること，さらに GPS，マイクの利用は端末の電力消費やプライバシの問題から，常時計測に適用するのはまだ現実的でない．

これらの従来研究の問題点に対し，本稿では日常計測に適した消費カロリー推定システムを提案する．本システムは，携帯端末に搭載した加速度センサを使用して，端末の所持状態やユーザの差異に依存することなく高精度にユーザの移動状態を推定し，消費カロリーを導出する．また常時計測を想定し，移動状態推定における処理負荷を可能な限り抑えた手法を提案する．

本稿の構成は，まず 2 章で消費カロリー推定システムの要件を列挙し，3 章において我々の提案する消費カロリー推定システムの処理概要を記載する．4 章において実証実験を通して提案手法の有効性を評価し，5 章で本稿をまとめる．

2. システム要求

本章では日常計測を想定した消費カロリー推定システムの要件を記述する．本稿で提案するシステムは，一般利用者が 1 日の活動状況を日々確認し，運動計画や食生活を管理するためのサポートツールとして使用することを想定している．したがって，推定結果には一定の精度が要求されるものの，医療用途で要求される正確性を追求するのではなく，利用の手軽さも要求される．これをふまえ，以下をシステムの要件とする．

（**要件 1**）携帯電話端末での推定

日常計測を想定した場合，計測機器の設置作業の手間を軽減すること，また，通常行動を妨げないことを考慮すると，専用のデバイスを利用するのではなく，常時ユーザが携行するデバイスに消費カロリー推定機能を付加するのが望ましい．そこで，加速度センサ内蔵の携帯電話端末を利用して消費カロリー推定を実行することを前提とする．

（**要件 2**）端末の所持状態に対してロバストな推定であること

携帯電話端末は多目的で利用されることから，特定の箇所に装着，設置して計測するのは実用的ではない．したがって，端末の所持状態に関係なく，移動状態を推定できる必要がある．

（**要件 3**）ユーザごとに学習の必要がない

ユーザごとに学習すれば推定精度の向上を見込めるが，利用者が学習用データを作成する必要があり，大きな負担となる．そのため，ユーザごとの学習処理が不要である必要がある．

（**要件 4**）処理負荷の軽減

常時計測を行うこと，携帯端末へ実装することをふまえると可能な限り消費電力を少なくすることは必須である．そのため推定に要する処理負荷は可能な限り抑える必要がある．

なお，本稿において消費カロリーの推定誤差は，文献 17) で示された 20%以下を目標とする．

3. 移動状態推定による消費カロリー推定方式

本章では 2 章であげた要件に従う消費カロリー推定システムを提案する．（**要件 2**）（**要件 3**）にあげたように，端末の所持状態の差異や瞬間的な姿勢の変化，また個々人の動作の差異に対しても，ロバストに推定が行える必要がある．そこで，提案システムでは加速度の

© 2011 Information Processing Society of Japan

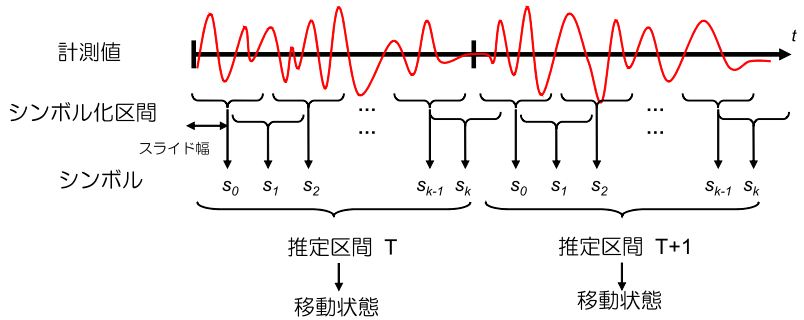

図 1　シンボル化区間と推定区間
Fig. 1　Symbolization term and estimation term.

一定期間の計測値をシンボル化した後，さらにより長い区間に着目して，複数のシンボルの時系列データから確率的に移動状態を推定する．ここで，加速度計測値をシンボル化する区間をシンボル化区間，複数のシンボルを基に移動状態を推定する区間を推定区間，シンボル化を実施する時間間隔をスライド幅と定義する（**図 1**）．

提案システムは主に以下の 3 ステップで構成される．

- シンボル化処理
- 移動状態推定処理
- METs-消費カロリー推定処理

携帯端末搭載の加速度センサの計測値をシンボル化する．次に図の推定区間内のシンボルの時系列データから確率的に移動状態を推定する．最後に推定された移動状態と，計測値の大きさから，消費カロリーを推定する．以降で各処理の詳細について記述する．

3.1　シンボル化処理

シンボル化処理では，時系列の加速度センサ計測値の特徴量をあらかじめ決められたシンボルに変換する．（**要件 2**）において，提案システムでは携帯端末を特定の場所に固定しないことをあげていることから，逐次変化する携帯端末の所持状態や姿勢に関係なく処理できるよう，3 軸加速度センサの計測値を合成加速度成分に変換する．変換式は以下に記す．

$$a(t) = \sqrt{x(t)^2 + y(t)^2 + z(t)^2} \tag{1}$$

ここで，$x(t)$，$y(t)$，$z(t)$ はそれぞれ時刻 t における 3 軸加速度センサの計測値であり，$a(t)$ はその合成成分を表す．$a(t)$ の時系列データはシンボル化区間ごとに分割され，各シンボル化区間のパワースペクトルを高速フーリエ変換（FFT：Fast Fourier Transform）を利用して導出する．ここで計算されたパワースペクトルをあらかじめ導出しておいた代表パワースペクトルと比較し，最小誤差の代表スペクトルのシンボルを観測値に割り当てる．

割当ての処理は以下の式で表される．

$$symbol(p) = \arg\min_{s} \left(\sum_{f} |P_f(s) - p_f| \right) \tag{2}$$

ここで，s は代表パワースペクトルのシンボル，f は FFT によって得られる各周波数，p は計測値から得られるパワースペクトル，p_f は p における周波数成分 f の値，$P_f(s)$ はシンボル s の代表パワースペクトルを表す．本シンボル化処理において各シンボルに対応する代表パワースペクトルはあらかじめ収集した学習データに対して，k-means を利用して生成するものとする．提案手法では k-means によって 120 種の代表パワースペクトルを選択し，計測値を式 (2) に従い，いずれかのシンボルに変換した．

3.2　移動状態推定処理

加速度センサで得られる計測値は，計測中の行動によって意味が異なるため，行動推定は，消費カロリー推定の精度を決定する大きな要因である．提案システムでは，日常生活での行動推定対象として，以下の 5 種の移動状態に着目した．

- STOP（停止）
- WALK（歩行）
- RUN（走行）
- BIKE（自転車）
- MOTOR（電車，自動車，バス）

また，より詳細に移動状態を推定するため，WALK においては NORMAL（通常），UP-STAIR（階段上り），DOWNSTAIR（階段下り）の識別を行う．**図 2** に示すとおり，まずは MoveClassifier において 5 つの移動状態を推定した後，移動状態推定が WALK であった場合には，WalkClassifier においてより詳細な歩行状態を推定する．

携帯電話のように所持状態や姿勢が逐次変化する場合，異なる移動状態であっても瞬間的には似たような波形が計測されることがある．短時間の計測で得られたシンボルごとに移動状態を推定すると，推定精度が悪化する可能性が高い．端末の所持状態や突然の姿勢の変化に対して，ロバストに移動状態を推定するため，提案手法では時系列上の複数のシンボルを利用して確率的に移動状態を推定する．たとえばシンボル化区間を 2 秒，スライド幅を

© 2011 Information Processing Society of Japan

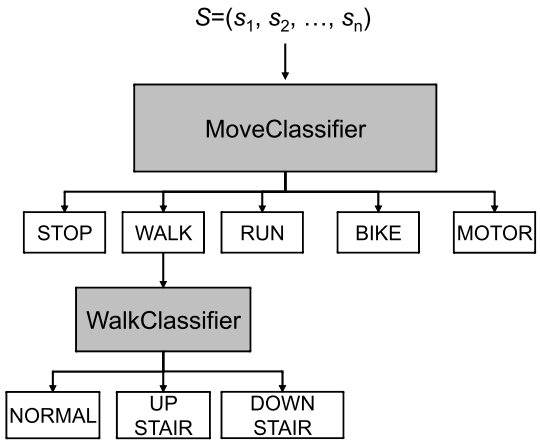

図 2　移動状態推定システムの推定手順
Fig. 2　Locomotion estimation process.

1 秒，推定区間を 30 秒とすると，30 個のシンボル時系列を入力として移動状態推定を行うことになる．推定区間内のシンボル時系列に対し，提案手法では Naïve Bayes 分類器を使用して確率的に移動状態を推定する．Naïve Bayes 分類器での推定は以下の式で表される．

$$Class = \arg\max_{c} \Pr(C = c) \prod_{i=1}^{n} \Pr(X_i = x_i \mid C = c) \tag{3}$$

ここで C は分類器において推定対象となる移動状態変数，c は各移動状態，X_i は分類器への入力ベクトルの i 番目の要素を示す変数，x_i は X_i のとる値，n は入力ベクトルの次数を表す．また，$\Pr(C = c)$ は移動状態が c となる確率，$\Pr(X_i = x_i \mid C = c)$ は移動状態が c のとき，入力ベクトルの i 番目の要素 X_i が x_i となる確率を表し，ともに学習データから求められる．

また提案手法では，Naïve Bayes 分類器への入力ベクトルとして，推定区間内のシンボル時系列に含まれる各シンボルの出現率を使用する．ここで全シンボルの出現率を用いて推定する場合，分類器への入力ベクトルの次数 n は，シンボル種別数だけ必要となり，それに応じた計算量が必要となる．（**要件 4**）の処理負荷軽減のため，提案手法では，一部のシンボルを特徴シンボルとして定義し，入力シンボル時系列内における各特徴シンボルの出現率を入力ベクトルとする．これにより入力ベクトル数 n が減り，計算量を低減することが可能となる．

特徴シンボルの選択

特徴シンボルの選択は，分類器の学習過程において事前に実施する．移動状態に対する各シンボルの情報利得から，移動状態推定における寄与度を求めることができる．S の情報利得は以下の式で導出される．

$$InfoGain(S) = H(C) - H(C \mid X_S) \tag{4}$$

ここで X_S はシンボル S の入力シンボル時系列中の出現率を表す変数で $H(C)$ はエントロピー，また $H(C \mid X_S)$ は条件付きエントロピーであり，以下の式で表される．

$$H(C) = -\sum_{c \in C} \Pr(c) \log \Pr(c) \tag{5}$$

$$H(C \mid X_S) = -\sum_{x_S \in X_S} \Pr(x_S) H(C \mid x_S) \tag{6}$$

情報利得が大きいシンボルほど移動状態の分類に寄与することを示している．特徴シンボル選択の詳細な手順は以下のとおりである．

1)　学習データに対して以下の式に従うシンボル s をシンボル群 S_0 に追加する．

$$\max_{c} \Pr(s \mid c) > N$$

ここで N は定数である．

2)　S_0 をシンボル $s \in S_0$ の情報利得の降順にソート．

3)　$k = 1$ に設定．

4)　学習データにおいて，S_0 の上位 k 個のシンボル（s_1〜s_k）を特徴シンボルとしたときの推定精度を $D(k)$ とし，$D(k)$ および $D(k+1)$ を導出．

5)　k が以下の式を満たす場合は，S_0 の上位 k 個のシンボルを着目する特徴シンボルとする．満たさない場合は $k = k + 1$ として 4) の処理へ戻る．

$$D(k+1) - D(k) < \varepsilon$$

ここで ε は定数である．

実際には推定精度と計算処理量のトレードオフによって，N および ε を決定し特徴シンボルを選択することになる．なお，提案手法では N を 0.001 とし，特徴シンボル数 n は MoveClassifier において 20 個，WalkClassifier において 10 個とした．

上記のように，特徴シンボル選択処理を行うことと，移動状態推定において MoveClassifier と WalkClassifier の 2 段階の推定を行うことは，処理負荷軽減の観点から有効である．なぜなら，MoveClassifier と WalkClassifier では推定対象となる移動状態間の類似度が異なる

© 2011 Information Processing Society of Japan

ため，必要となる特徴シンボルが異なる．これを 1 段の分類器で推定すると，MoveClasifier と WalkClassifier の双方の識別に有効なシンボルを特徴シンボルに含める必要があり，1 つの分類器で使用する特徴シンボル数 n が増加し，結果として処理負荷も増加する．一方，2 段階推定では，最初の分類で Walk と推定されたときのみ WalkClassifier による推定を実施すればよく，また各分類器で必要となる特徴シンボル数を減らすことが可能であるため，全体として計算量が減少する．

3.3　METs-消費カロリー推定処理

移動状態推定処理の後，加速度計測値と移動状態ごとに決まった処理，および被験者の体重から消費カロリーを推定する．提案方式では，METs（Metabolic Equivalents）と呼ばれる指標を使用する．METs とは単位時間あたりの運動量によって定義されるものであり，体質に依存しない指標として利便性が高く，現在広く使用されている．METs と消費カロリーの関係は以下のように表される[14]．

$$(EE) = 1.05 \times (METs) \times (Weights) \times T \tag{7}$$

EE は消費カロリー，T は運動時間である．METs 値は運動の種類とその運動の大きさによって決定される．文献 2)–4) で述べられているとおり，各移動状態における消費カロリーは運動によって生じる加速度の大きさに比例する．ただし，加速度センサには常時，重力加速度が加算されて計測されるため，計測値から振動成分のみを抽出する必要がある．そこで，提案手法ではシンボル化区間の標準偏差を運動の大きさに比例する量と見なした．したがって，METs の計算は以下の式で導出される．

$$METs = a_i \times (ACC) + b_i \tag{8}$$

ACC は合成加速度成分のシンボル化区間における標準偏差である．a_i，b_i は移動状態 i によって決定される係数である．提案手法では各移動状態の学習データから線形回帰によってこれらの係数を事前に決定する．以上により，移動状態推定結果，加速度計測値の標準偏差と式 (7)，(8) から単位時間あたりの消費カロリー量を導出する．

4.　評　　価

本章では提案手法の有効性を検証する．検証のため，我々はデータ収集実験，および日常計測実験の 2 つのフィールド試験を実施した．データ収集実験の目的は移動状態推定における各分類器の学習と特徴シンボル選択に使用する学習データを収集すること，および式 (8) における METs 導出の係数を決定することである．さらにデータ収集実験では，移動状態推定精度の検証も行う．日常計測実験では，提案方式を実装した端末を日常生活内で利用してもらい，消費カロリーの推定精度を評価する．なお，本評価において加速度計測値をシンボル化するにあたり，シンボル化区間は 2 秒とした．これは文献 11) の評価結果に基づいており，推定対象とする移動状態の識別には 0.5 Hz 以下の低周波成分があまり寄与しないためである．また，シンボル化区間のスライド幅に関して，文献 11) では小さいほど推定結果が良くなることが示されているが，本評価では処理負荷もふまえ 1 秒とした．

(a)W62CA　　(b)SenseWear

図 3　計測用センサデバイス概観
Fig. 3　Measurement devices used in the field experiment.

4.1　計測センサデバイス

フィールド試験ではデータ計測，推定処理用のデバイスとして，すでに商用利用されている携帯電話端末 W62CA [12] を使用した．本端末は 3 軸加速度センサを搭載しており，16 Hz サンプリングレートで計測可能である．提案手法の消費カロリー推定処理を本端末に実装し，計測結果および推定結果をリアルタイムに携帯電話端末に装着した MicroSD メモリカードに出力する．**図 3** (a) に本端末の概観を示す．また消費カロリーの正解データの計測用に SenseWear（図 3 (b)）を使用した．

4.2　フィールド試験 1：データ収集実験

4.2.1　実 験 環 境

データ収集実験では，128 名の被験者を対象に各移動状態における加速度と消費カロリーを計測した．被験者構成を**表 1** に示す．各被験者には 3 台の W62CA 端末をそれぞれ手（HND），ポケット（PKT），バッグ（BAG）に持ってもらい計測を実施した．提案システムの推定処理に汎用性を持たせるため，学習データの収集では，端末を設置するポケットを指定せず，胸ポケット，コートのポケット，ズボンのポケット等，被験者の普段の利用状況と同じ条件となるようにした．また，バッグについても被験者が普段使用しているものを本実験でも使用した．また各被験者の腕には SenseWear を装着し，消費カロリーを計測した．全被験者には推定対象となる移動状態ごとに 2 分から 30 分のルーチンワークを実施してもらっ

© 2011 Information Processing Society of Japan

表 1　被験者構成（フィールド試験 1）
Table 1　Subjects in field experiment 1.

	Male	Female	Total
20–29	22	28	50
30–39	29	17	46
40–49	22	2	24
50–59	8	0	8
Total	81	47	128

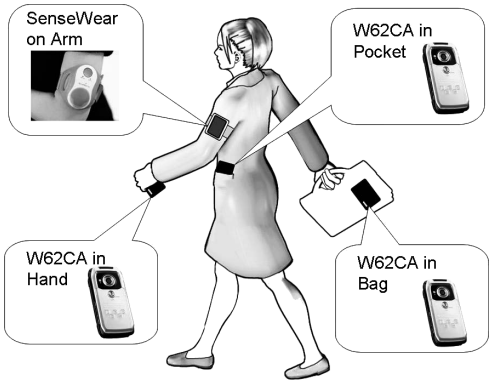

図 4　計測センサデバイス装着場所
Fig. 4　Installed position of each measurement device.

た．“WALK” と “RUN” においては，速度を指定せず被験者の判断に任せることとした．

4.2.2　移動状態推定精度の評価

データ収集実験で得られたデータに対する，移動状態推定精度を F 値によって評価する．F 値は推定結果の適合率と再現率によって以下の式で表される指標であり，高いほど精度の良さを示す．

$$F = \frac{2PR}{P+R} \tag{9}$$

P は適合率（Precision），R は再現率（Recall）を表す．本評価において検証する手法は**表 2** のとおりである．提案手法では推定区間を 10 秒，および 30 秒と設定した場合の推定精度

表 2　評価対象とする推定方式
Table 2　Evaluated methods in the field experiment.

提案（T=10）	提案方式．推定区間を 10 秒
提案（T=30）	提案方式．推定区間を 30 秒
従来方式 1	1 回の計測シンボルのみから移動状態を推定
従来方式 2	従来方式 1 において，所持状態 PKT のデータのみを学習データとして使用

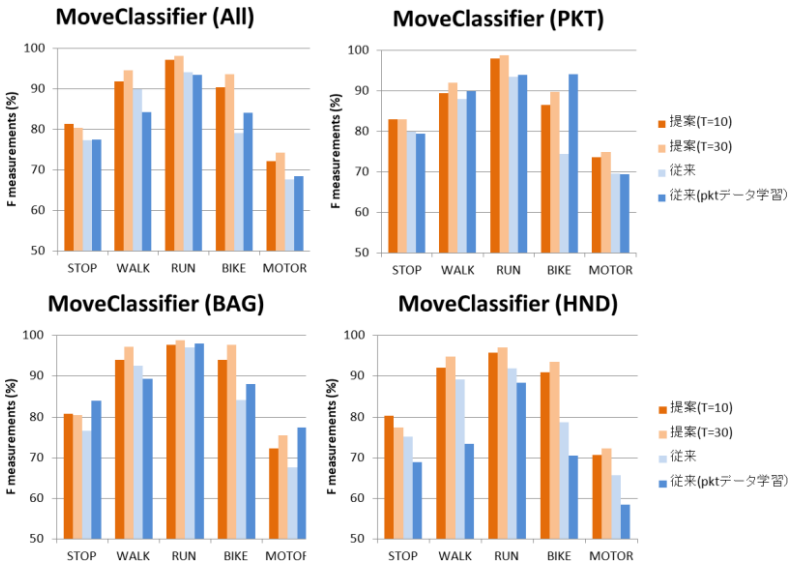

図 5　各端末所持状態に対する MoveClassifier の推定精度（F 値）
Fig. 5　Estimation accuracy of MoveClassifier for each posture (F-measurements).

を評価する．また，比較対象は計測値から得られる単一のシンボルから移動状態を推定するものとして，文献 9) 等の従来方式に相当する．なお文献 9) では所持状態としてポケットのみのデータを使用していることから，従来手法 2 として，所持状態ポケットの計測データのみで学習した場合の推定結果も比較用に評価した．

図 5 に MoveClassifier での各手法の推定精度の F 値を示す．従来手法 2 は，学習データ

© 2011 Information Processing Society of Japan

として PKT のみの計測データを使用しているため，PKT における推定精度は特に BIKE において良く，提案手法よりも高くなっている．これは，ポケット内の端末に自転車のペダルをこぐ動作の加速度振動が伝わりやすいことにより，他の移動状態との識別が容易になったためであると考えられる．また BAG においても STOP，MOTOR で提案手法よりも良い推定精度となっている．しかしながら，HND においては他の 2 つの所持状態に比べ大幅に推定精度が下がっている．一方，3 つの所持状態の計測データを学習データとした従来手法 1 では所持状態への依存性は抑えられ，HND における推定精度が改善されるものの，その分 PKT や BAG の推定精度が落ちている．これらの従来手法に対し，提案手法 1，および 2 は各所持状態に対しても従来手法ほど誤差が変化することがなく，かつ高い推定精度を確保していることが分かる．

WalkClassifier における推定精度を**図 6** に示す．MoveClassifier の場合と同様の傾向が見られるが，MoveClassifier よりも提案手法による改善が大きい．WalkClassifier のように識別対象とする移動状態が似ている場合，同じシンボルを出力する可能性が高くなり，さらに個々人の動作や所持状態の差異も加わって，瞬間的な識別がより困難になるからである．このような場合でも，提案手法は特定のシンボルの出現率から確率的に移動状態を推定することで，高い識別精度を維持している．

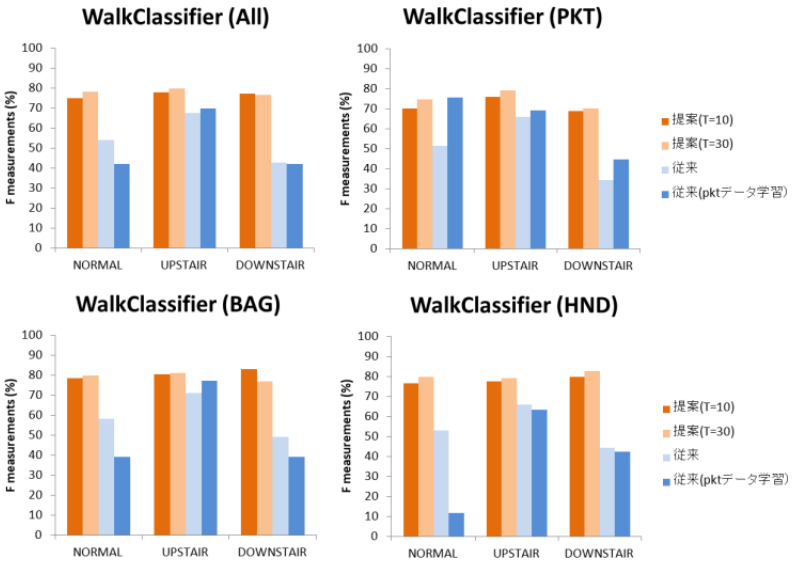

図 6　各端末所持状態に対する WalkClassifier の推定精度（F 値）
Fig. 6　Estimation accuracy of WalkClassifier for each posture (F-measurements).

4.2.3　消費カロリー推定用係数の導出

本フィールド試験で収集した移動状態ごとの SenseWear の METs 値と W62CA の加速度値から線形回帰によって式 (8) の各係数を導出した．**図 7** に STOP，WALK，RUN における全被験者の加速度値と METs 値の関係を示す．また移動状態ごとの線形回帰による消費カロリーの推定誤差の平均値を**表 3** に示す．これは正しく移動状態を推定できたとしても，被験者の体質の差や端末の所持状態の差異等の影響で消費カロリーの推定値にこれだけの差が生じることを意味している．STOP，MOTOR においては，ほとんど動きがないため，基礎代謝量の個人差の影響を相対的に受けやすく，WALK や RUN よりも推定精度が悪くなる．BIKE での誤差が大きいのは，加速度センサには被験者の運動以外に地面の凹

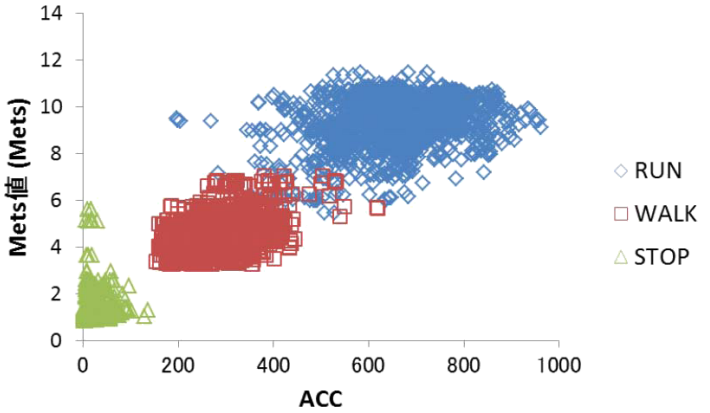

図 7　RUN，WALK，STOP における加速度標準偏差と METs 値の関係
Fig. 7　Relation between acceleration and METs in RUN, WALK, and STOP motion.

表 3　各移動状態における消費カロリー推定誤差
Table 3　Averaged accuracy of energy expenditure for each locomotion.

	STOP	WALK	RUN	BIKE	MOTOR
推定誤差(%)	14.8	11.1	9.4	15.3	14.5

© 2011 Information Processing Society of Japan

凸による自転車の振動が加わるため，RUN や WALK に比べ運動の激しさのみを正確に抽出するのが難しいことが原因と考えられる．

4.3　フィールド試験 2：日常計測実験

本実験では，データ収集実験で学習された移動状態推定処理と式 (8) の係数を使用して，日常生活における提案手法の消費カロリー推定精度を評価する．

4.3.1　実 験 環 境

フィールド試験においては 11 名の異なる職業の被験者に計測デバイス W62CA と SenseWear を携帯した状態で通常の生活をしてもらい，8–15 時間の計測を実施した．W62CA の所持状態は指定せず，被験者がいつも所持している状態で携帯してもらった．なお，W62CA は各被験者が通常使用する携帯端末とは異なっていたため，本端末での通話や電子メールを依頼することはできなかったが，できるだけ実利用時の影響を反映させるため，携帯でのインターネットは本端末での利用を依頼した．

また，参考情報として市販の消費カロリー計測デバイス OMRON 社製 Active style Pro [13] も装着した．本デバイスは腰に固定した加速度センサの計測値を基に，歩行，走行等の歩行活動のほか，掃除，洗濯等の家事を “生活活動” として識別して METs 値を計測することが可能なデバイスである．本実験においても，腰に固定して理想的な環境で計測を行った．

本実験において W62CA は推定区間を 10 秒と 30 秒に設定して移動状態推定と消費カロリー導出を逐次実施し，MicroSD に記録する．また被験者には一定間隔ごとに動作の概要を記録してもらった．**表 4** に被験者の構成を記す．

4.3.2　評 価 結 果

図 8 に各被験者の消費カロリー推定結果を記す．SenseWear の計測値との平均誤差は提案手法 1 で 12.6%，提案手法 2 では 11.8%であった．このうち 15%以上の推定誤差があるユーザは被験者 3，8 であった．SenseWear は加速度以外にも体温を計測していることから，加速度では検知できないカロリー消費，たとえば発話にともなう体温上昇や食事誘発性熱代謝（DIT，Diet Included Thermogenesis）の影響を計測でき，結果として加速度センサのみでの推定値よりも高めになる傾向がある．しかし被験者 3 においては，SenseWear の計測値に比べ提案手法の推定値が大幅に大きくなっている．Active style Pro においても SenseWear の計測値より高くなっており，加速度センサにおいて大きな運動が計測されているにもかかわらず，実際の消費カロリー量が少なかったことから，被験者の基礎代謝量が極端に低かったことが原因と考えられる．

一方，被験者 8 は移動状態推定で大きく誤ることがなかったものの，停止時や電車移動においては推定値よりも常時 30%以上高い METs 値が SenseWear で計測されており，基礎代謝量が非常に高い被験者であったことが予想される．

その他の被験者のうち，会社員，および劇団員の行動の多くが，提案手法で推定対象と

表 4　日常計測実験の被験者構成
Table 4　Subjects in field experiment 2.

被験者	性別	年齢	職業
1	女性	34	主婦
2	女性	33	主婦
3	女性	36	劇団マネージャ
4	男性	27	劇団員
5	女性	23	劇団員
6	男性	47	会社員
7	男性	35	会社員
8	男性	35	会社員
9	女性	25	会社員
10	女性	27	会社員
11	女性	37	会社員

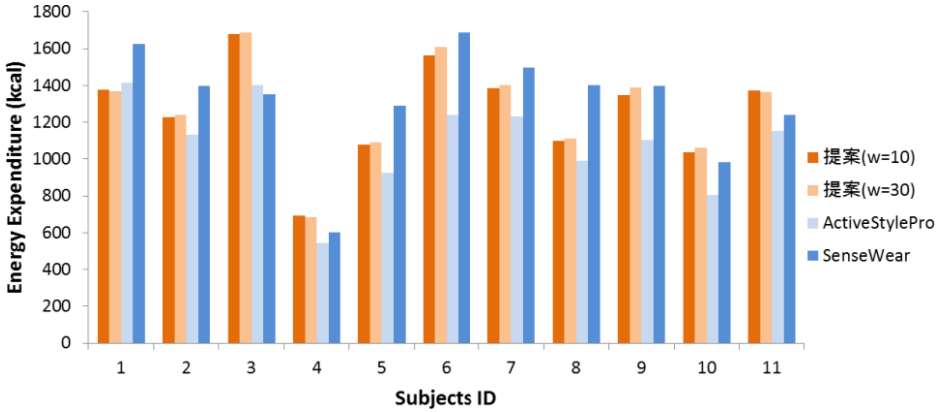

図 8　日常計測における消費カロリー推定量
Fig. 8　Result of energy expenditure estimation in daily usage.

© 2011 Information Processing Society of Japan

した移動状態で分類できるものであり，また移動状態推定を誤ることがあまりなかった．一方，主婦の場合，洗濯や食器洗い等の家事をしている時間帯において，MOTOR か BIKE と推定される場合があった．

Active style Pro と比較した場合，提案手法は歩行，走行以外に自転車や自動車，電車，バス等の移動状態を識別することができるため，より詳細に消費カロリーを推定できると期待される．実際に，Active style Pro の誤差は全体平均で 17%であり，提案手法よりも大きかった．特に電車・自転車を利用する可能性の高い会社員において，提案手法の効果は大きく現れており，Active style Pro の誤差 19%に対して，提案手法 1，2 の推定誤差はそれぞれ 9%，8%であった．これは Active style Pro が，これらの移動状態においては停止と判断し，消費カロリーを過小評価したためと考えられる．一方，主婦においては，家事を生活活動として識別する Active style Pro の利点が現れており，被験者 1 においては，Active style Pro の誤差の方が若干小さくなっている．主婦の平均では Active style Pro の誤差が 15%であるのに対し，提案手法 1，2 の誤差はともに 13%であった．

4.4 考　　察

4.4.1 推 定 精 度

フィールド試験 1 による評価では提案手法における移動状態推定の優位性を示した．提案手法では，端末の所持状態の差異や姿勢の変化，被験者個々人の差異に対して精度良く移動状態を推定するために，加速度計測値から得られるシンボルの時系列データに対して確率的に移動状態を推定しており，図 5，図 6 においてその効果が示された．本結果では，概して推定区間の長い提案手法 2 の方が提案手法 1 より推定精度が良くなる傾向にあるが，STOP においては推定手法 1 の推定精度が良くなっている．これは被験者が長時間停止することが難しく，MOTOR との識別に失敗することが原因と考えられる．また，推定区間を長くすると時間の分解能が低下するため，短時間で動作が変化するような移動状態の場合は，消費カロリー推定において精度が落ちる可能性がある．このような問題を回避するには，まずは推定時間を短時間に設定しておき，推定される移動種別とその確度に応じて推定区間を動的に変化させる方法等が考えられる．

消費カロリー推定において，フィールド試験 2 では，提案手法は SenseWear の計測値と比較して 12〜13%の誤差となった．2 章で述べたとおり，提案システムは日々の運動計画や食生活の管理をサポートする簡易的なツールとしての使用を想定している．食生活の観点から考えると，たとえばご飯 1 膳（約 140 g）のカロリーは 235 kcal[19] であるが，フィールド試験 2 の多くの被験者で，提案手法は 100 kcal 前後の誤差に抑えられていることから，計測結果を基に食事量のコントロールを行うことが可能な精度を達成しているといえる．一方，加速度計測値から METs 値に変換する式 (8) の係数は，フィールド試験 1 での SenseWear の計測値から求めたが，SenseWear にもダグラスバック法と比較して 7%ほどの推定誤差が含まれている[1]．これを考慮すると提案手法のダグラスバック法と比較した推定誤差は 20%以下になると期待される．今後，より厳密な消費カロリー推定を実現するためには，ダグラスバック法での計測が必要となる．

フィールド試験 2 では，4.3.1 項で記載したとおり，本計測では携帯端末の通話や電子メールでの使用の影響が含まれていない．これらの携帯端末利用により発生する振動は，歩行や走行のそれに比べて非常に小さいため，歩行・走行時の消費カロリー推定にはほとんど影響がないと予想される．一方，停止状態では，これらの影響を受け，MOTOR か BIKE と識別される可能性があり，その結果推定される消費カロリー量が実際よりも多くなると予想される．しかしながら，携帯端末側でサービスの利用状況を監視することが可能なため，たとえば加速度計測値に対して適切なフィルタをかける等の対応によって，これらの影響を軽減できると考えられる．

4.4.2 処 理 負 荷

シンボル化処理から直接移動状態を推定する文献 9) の手法と比較した場合，提案手法では，推定精度向上のために，シンボル化処理の後，さらにその時系列データに対して確率推定を実行するため，処理負荷は増える．しかし，シンボルの時系列データに対する処理負荷を抑えるため，提案手法では，情報利得の利用と推定処理を 2 段階に分離している．ここでは，その効果を定量的に評価するため，シンボル時系列データを扱う同様の処理として隠れマルコフモデル（HMM，Hidden Markov Model）を使用した文献 11) の処理負荷との比較を行う．具体的には処理負荷の指標として計算量とメモリ使用量の観点で提案手法が文献 11) に対して持つ優位性を示す．

(1)　計算量

文献 11) では学習によって生成された移動状態ごとの HMM に対して，観測シンボル時系 Pro 列を出力する尤度を計算し，最も尤度の高い HMM に対応する運動状態を推定結果として出力していた．HMM において，ある移動状態に関する尤度計算にともなう計算量は，Forward Probability を使用した場合，

$$O(N_s^2 T) \tag{10}$$

となる[15]．ここで N_s は各 HMM の状態数，T は観測系列長である．HMM での推定精度を上げるには状態数および観測シンボル長を増やすことになるが，これにともない計算量は

© 2011 Information Processing Society of Japan

指数関数的に増加する．

一方，提案手法では観測シンボル系列に含まれる特徴シンボルの割合を入力とした Naïve Bayes 分類器によって移動状態ごとの尤度を計算する．Naïve Bayes 分類器では，ある移動状態の尤度を式 (3) で導出する計算量は入力ベクトルの次元数 n となる．n は，提案手法において特徴シンボル数に相当することから，特徴シンボル数を N_r とすると，その計算量は

$$O(N_r) \tag{11}$$

となる．さらに提案手法では，情報利得を利用して特徴シンボル数 N_r を効果的に減らすことができる．文献 11) では，$N_s = 30$，$T = 30$ であるのに対し，提案手法では $N_r = 20$ としていることから，HMM に比べ，約 1,350 分の 1 の計算負荷に軽減できていることが分かる．

(2)　メモリ使用量

HMM は以下に示す各状態間の遷移確率および，各状態におけるシンボルの出力確率で表現される．

- 遷移確率　$a(i, j)$（$1 \leq i,\ j \leq N_s$）
- 出力確率　$b(i, k)$（$1 \leq i \leq N_s$，$1 \leq k \leq N_{r0}$）

そのため，HMM で必要となるメモリ量は，識別対象となる移動状態 1 つにつき，

$$O(N_s(N_s + N_{r0})) \tag{12}$$

となる．ここで N_{r0} は加速度計測値から出力されうるすべてのシンボル種別数である．

一方，Naïve Bayes 分類器では，式 (1) における入力ベクトル数 n と，$\Pr(X_i = x_i \mid C = c)$ の数，つまり各入力ベクトルのとりうる値の数だけメモリを使用する．提案手法では分類器への入力ベクトルとして着目するシンボル数を情報利得により低減しており，その数を N_r としている．特徴量のとりうる値は推定区間での出現率であるため，推定区間長 T に対して $(T + 1)$ の値だけの確率が必要となる．したがって使用メモリ量は，

$$O(N_r(T + 1)) \tag{13}$$

である．文献 11) では $N_s = 30$，$N_{r0} = 120$ となる．これに対し，提案手法では $N_r = 20$，$T = 30$ であり，HMM に比べ 7 分の 1 以下のメモリ使用量となる．着目するシンボルを情報利得を基に特徴シンボルとして減らした分，メモリ使用量を低減することができることが分かる．

以上の計算量とメモリ使用量の双方の評価において，文献 11) の手法に対する提案手法の処理負荷における優位性が示された．

5. ま と め

本稿では携帯電話端末搭載の加速度センサを利用した消費カロリー推定システムを提案した．提案システムでは，加速度計測値をシンボル化した後，一定区間のシンボル時系列データから STOP，WALK，RUN，BIKE，MOTOR の 5 種の移動状態を識別し，さらに WALK の場合には通常歩行と階段昇降との識別を行い，得られた移動状態から消費カロリーを推定する．

移動状態の識別では，計測で得られたシンボルの時系列データに対して，特定のシンボルの出現率から確率的に移動状態を推定することで，端末の所持状態や姿勢，利用者個々人の差異に対してロバストに移動状態を推定できる．また識別時に着目するシンボルを情報利得によって選択することで，推定処理にともなう計算量を削減することができる．多くの被験者をともなった評価実験において，提案手法の優位性が示された．

また消費カロリーの推定では，移動状態推定で得られた結果と加速度計測値から METs 値を求め，最終的に消費カロリーを導出する．フィールド試験で得られた 128 名の学習データから加速度値と METs 値の変換式を決定し，日常利用時において，12–13%の誤差で消費カロリーを推定できることを示した．

今後は，推定対象の移動状態種別を増やし，消費カロリー推定精度の改善を行う予定である．

参 考 文 献

1) SenseWear. http://www.sensewear.com/
2) Bouten, C.V., Verboeket-van de Venne, W.P., Westerterp, K.R., Verduin, M. and Janssen, J.D.: Daily physical activity assessment: Comparison between movement registration and doubly labeled water, *J. Appl. Pysiol.*, Vol.81, pp.1019–1026 (1996).
3) Hendelman, D., Miller, K., Baggett, C., Debold, E. and Freedson, P.: Validity of accelerometry for the assessment of moderate intensity physical activity in the field, *Med. Sci. Sports Exerc.*, Vol.32, pp.S442–449 (2000).
4) Choi, J.H., Lee, J., Hwang, H.T., Kim, J.P., Park, J.C. and Shin, K.: Estimation of activity energy expenditure: Accelerometer approach, *Proc. 27th Annual Conf. on IEEE Engineering in Medical and Biology Society*, Shanghai, China, pp.3830–3833 (Sep. 2005).
5) Kem, N.: A model for human interruptability: Experimental evaluation and auto-

© 2011 Information Processing Society of Japan

matic estimation from wearable sensors, *ISWC 2004*, pp.158–165 (2004).
6) Intille, S.S.: Acquiring in situ training data for context-aware ubiquitous computing applications, *CHI 2004*, pp.1–9, ACM Press (2004).
7) Bao, L. and Intille, S.S.: Activity recognition from user-annotated acceleration data, *Proc. Pervasive 2004*, Vol.LNCS 3001, pp.1–17 (2004).
8) Wang, N., Ambikairajah, E., Lovell, N.H. and Celler, B.B.: Accelerometry based classification of walking patterns using time-frequency analysis, *Proc. 29th Conf. on IEEE Engineering in Medical and Biology Society*, Lyon, France, pp.4899–4902 (Aug. 2007).
9) Iso, T. and Yamazaki, K.: Gait analyzer based on a cell phone with a single three-axis accelerometer, *ACM 8th Conference on Human-computer Interaction with Mobile Devices and Services*, pp.141–144 (2006).
10) Kawahara, Y., Ryu, N. and Asami, T.: Monitoring daily energy expenditure using a 3-axis accelerometer with a low-power microprocessor, *Proc. Human Computer Interaction*, Vol.1, No.5, pp.145–154 (2009).
11) Kobayashi, A., Iwamoto, T. and Nishiyama, S.: UME: Method for estimating user movement using an acceleration sensor, *Proc. 8th International Symposium on Applications and the Internet*, pp.169–172 (2008).
12) au：W62CA. http://k-tai.casio.jp/products/w62ca/
13) Omron：Active style Pro.
http://www.healthcare.omron.co.jp/product/hja350it_1.html
14) 厚生労働省：健康づくりのための運動指針 (2006).
http://www.mhlw.go.jp/bunya/kenkou/undou01/pdf/data.pdf
15) 北　研二：言語と計算 4 確率的言語モデル，東京大学出版会 (1999).
16) Haapalainen, E., Laurinen, P., Roning, J. and Kinnunen, H.: Estimation of exercise energy expenditure using a wrist-wornAccelerometer: A Linear Mixed Model Approach with Fixed Effect Variable Selection, *Proc. Int'l Conf. on Machine Learning and Applications* (2008).
17) Lester, J., Hartung, C., Pina, L., Libby, R., Borriello, G. and Duncan, G.: Validated caloric expenditure estimation using a single body-worn sensor, *Proc. Ubicomp2009* (2009).
18) Li, Z.: Exercises intensity estimation based on the physical activities healthcare system, *Proc., Int'l Conf. on Communications and Mobile Computing* (2009).
19) 簡単！栄養 and カロリー計算.
http://www.eiyoukeisan.com/calorie/gramphoto/kokurui/gohan.html

(平成 22 年 6 月 2 日受付)
(平成 22 年 11 月 5 日採録)

南川　敦宣（正会員）
2003 年京都大学工学部電気電子工学科卒業，2005 年同大学院情報学研究科修士課程修了．同年 KDDI（株）に入社．以来，研究所にて，DTN，ユビキタスアプリケーション，ITS，放送通信融合技術，ライフログ解析技術等に関する研究に従事．2009 年（社）電子情報通信学会学術奨励賞受賞．電子情報通信学会会員．

小林　亜令（正会員）
1996 年北海道大学工学部電子工学科卒業．1998 年同大学院工学研究科修士課程修了．同年 KDDI（株）（当時 KDD）入社．現在，（株）KDDI 研究所特別研究員．モバイルコンピューティング，SVG，通信放送融合技術，センサデータ解析技術，ITS 等の研究開発に従事．

横山　浩之（正会員）
1992 年京都大学工学部電子工学科卒業，1994 年同大学院修士課程修了．同年国際電信電話（株）（現，KDDI（株））入社．以来，研究所にて，ATM 網，移動通信網，IP 網，光パケット網の性能評価・設計に関する研究に従事．2007 年から，携帯端末で観測可能な情報を活用したアプリケーションに関する研究に従事．2000 年（社）電子通信学会学術奨励賞受賞．電子情報通信学会会員．博士（工学）．

© 2011 Information Processing Society of Japan